# 基于改进ShuffleNet V2的轻量级防风药材道地性智能识别

赵　毓[1]，任艺平[2]，朴欣茹[1]，郑丹阳[1]，李东明[1,3*]

（1. 吉林农业大学 信息技术学院，吉林长春 130118；2. 吉林农业大学 生命科学学院，吉林长春 130118；3. 无锡学院 物联网工程学院，江苏无锡 214063）

**摘　要：**［**目的/意义**］目前，对于防风药材产地和品质的鉴别方法主要是根据其物理或化学特征，其方法需对中药材进行分离提取，存在耗时长，费用高，专业性强，技术难度大等问题，不利于推广应用。随着深度学习的不断发展，其无需人工提取特征、分类精度高等优点被广泛应用在中药材的识别之中。［**方法**］针对大多数卷积神经网络模型在识别防风药材时计算量大、精度低的问题，本研究提出了一种改进的ShuffleNet V2的轻量级防风道地性识别模型。在不降低网络性能的情况下调整模型架构，减少模型参数量和计算量，用沙漏残差网络（Hourglass Residual Network）代替传统残差网络，同时引入SE（Squeeze-and-Excitation）注意力机制，把具有附加信道注意力的沙漏残差网络嵌入到ShuffleNet V2中，使用SiLU激活函数替换ReLU激活函数，丰富局部特征学习，从而提出轻量化的中药防风道地性识别模型Shuffle-Hourglass SE。为了验证本文所提出模型的有效性，选用VGG16、MobileNet V2、ShuffleNet V2和SqueezeNet V2四种经典网络模型进行对比实验。［**结果和讨论**］结果表明，本研究提出的模型Shuffle-Hourglass SE获得了最佳性能。在测试集上取得95.32%的准确率、95.28%的召回率，$F_1$分数达到95.27%，测试时间、模型大小为246.34 ms和3.23 M，不仅在传统CNN网络中是最优的，在轻量级网络中也具有较大优势。［**结论**］本研究所提出的模型在保持较高识别精度的同时占用较少的储存空间，有助于在未来的低性能终端上实现防风道地性的实时诊断。

**关键词：**防风；道地性识别；ShuffleNet V2；SE注意力机制；沙漏残差网络；中药材；轻量级模型

**中图分类号：**R282.5;TP391.4　　　**文献标志码：**A　　　**文章编号：**SA202304003

引用格式：赵毓, 任艺平, 朴欣茹, 郑丹阳, 李东明. 基于改进ShuffleNet V2的轻量级防风药材道地性智能识别[J]. 智慧农业(中英文), 2023, 5(2): 104-114.

ZHAO Yu, REN Yiping, PIAO Xinru, ZHENG Danyang, LI Dongming. Lightweight intelligent recognition of *Saposhnikovia Divaricata* (Turcz.) Schischk originality based on improved ShuffleNet V2[J]. Smart Agriculture, 2023, 5(2): 104-114.

## 1　引　言

中药材对人体疾病的预防及控制具有重要的作用。防风（*Saposhnikovia divaricata*（Turcz.）Schischk）是伞形科植物防风未抽薹的干燥根，微甘、味辛、性温，是中国东北地区具有解表祛风、止痉和胜湿之功效的著名道地药材，其道地产区位于内蒙古、吉林、辽宁和黑龙江四省交界处。目前，对于防风药材产地和品质的鉴别方法主要是根据其物理或化学特征[1]，但是无法对防风药材的道地性[2]质量优劣进行准确衡量。

目前已有相关研究对药材道地性进行建模识别。张冬月等[3]采用PEN3电子鼻系统对不同产地通关藤及其混淆品气味进行定量表征，建立真伪品及道地性识别模型，并采用判别因子分析验证模型的准确性，可达90%以上。刘飞等[4]利用傅里叶变换红外光谱结合判别分析对三七的道地性及产地

收稿日期：2023-04-07

基金项目：吉林省科技厅重点研发项目（20210204050YY）；吉林省教育厅科研项目（JJKH20210747KJ）；吉林省环保厅项目（202107）；吉林省生态环境厅科研项目（吉环科字第2021-07号）；通辽市科技局重点研发项目（TLCXYD202103）

作者简介：赵　毓，研究方向为计算机视觉、图像处理。E-mail：954445517@qq.com

*通信作者：李东明，博士，教授，研究方向为计算机视觉，图像处理及光学检测等。E-mail：ldm0214@163.com

进行鉴别研究，测试了11个县13个种植点的136株三七主根样品的红外光谱，预测正确率为76.5%。Zhang等[5]通过化学计量学方法，对不同产地的药材进行分类、区分和建模，最终实现产地追溯的目的。上述现代技术虽然解决了传统辨状论质的主观性强的问题，使鉴别数据化、客观化，在中药的道地性区分上有较好的应用前景，但其方法需对中药材进行分离提取，存在耗时长、费用高、专业性强、技术难度大等问题，不利于推广应用。

深度学习算法的出现大大提高了传统识别任务中的识别率，尤其是深度学习领域中的卷积神经网络（Convolutional Neural Networks，CNN），正在迅速成为图像识别的首选方法。人们提出对基于CNN模型进行各种修改，从而实现高精度和高速度处理视觉任务[6-9]。随着基于CNN模型的发展，研究人员提出了一系列优秀的网络，包括AlexNet[10]、VGGNet[11]、GoogLeNet[12]、ResNet[13]和DenseNet[14]等，并逐渐应用于植物病害严重程度识别的研究。

随着深度学习的不断发展，其无需人工提取特征、分类精度高等优点被广泛应用在不同领域，同时不断有研究将深度学习引入中药材的识别之中，其中中药材的种类和其质量的识别是重中之重。赵潇潇[15]利用CNN对不同产地的枸杞外观图像进行特征提取，最终实现枸杞道地性在线识别，准确率可达96%。李东明等[16]将协调注意力模型与残差模块进行融合，在迁移学习和数据扩充方式下新模型对中药材图像的识别准确率可达97.23%。Lyu等[17]收集了100种常见中药的图像，用目前主流的目标检测模型，结果显示YOLOv5模型在识别各种TCM（Traditional Chinese Medicine）方面有明显的优势，平均准确率为94.33%。Xing等[18]采用PyTorch和Keras框架，手工构建了一个DenseNet模型，用于识别各种中药，结合转移学习的思想，最高识别率可以达到97.5%。但是，大多数CNN由于自身深度且复杂的网络结构而具有较大的参数量和计算量，使得模型依赖于计算机能力强大的GPU难以应用于硬件资源有限的便携式设备，不利于实施中药材道地性的便捷识别。为了使CNN应用于移动端和嵌入式设备，一些研究人员提出了轻量化神经网络，例如Xception[19]、MobileNet[20]、MobileNet V2[21]和ShuffleNet V2[22]等。轻量化网络参数量较小、对内存要求较低，它们在速度和准确性之间实现了良好的平衡，适用于内存资源受限的移动端设备，目前，基于轻量化网络的识别已逐渐成为一个研究热点。刘雪纯等[23]对MobileNet V2的预训练模型参数进行多次微调，实现了12类中药材图片识别，最终在验证集上精度可达93%，训练时间上也比普通卷积神经网络节省了2倍以上。

本研究针对中药材防风同物种空间形态和颜色纹理特征较为复杂，区分度较低等问题，提出一种附加信道注意力的沙漏残差网络用于防风道地性识别，改进后的模型可以在保证高分类精度的同时减少对内存空间的占用，可以有效地应用于不同性能的硬件平台，为进一步开发低成本的基于终端的防风道地性自动识别系统提供技术和方法。

## 2 研究方法

### 2.1 深度可分离卷积

为了加快网络的计算速度并减少计算量，MobileNet网络提出了深度可分离卷积。传统的卷积使用$N\times N$卷积核通过卷积运算，深度可分离卷积分为深度卷积和逐点卷积[24]，相当于使用通道数为1的卷积核对输入特征的每个通道执行单独的卷积运算。输入图像大小为$H\times W$，$H$代表特征图的高度，$W$代表其宽度，N是输入通道的数量，卷积核的大小用$K\times K$表示，$M$和$N$分别表示卷积核和输出特征映射通道的数量，计算成本和深度卷积参数数量分别为$H\times W\times M\times N$和$MN$。

如公式（1）所示，深度可分离卷积计算成本与标准卷积计算成本的比率为：

$$\frac{H\times W\times N\times K^2+H\times W\times M\times N}{H\times W\times N\times K^2\times M}=\frac{1}{M}+\frac{1}{K^2} \quad (1)$$

在ShuffleNet V2中，$M$比$K^2$大得多，并且深度卷积内核大小K通常为3，因此与标准卷积相比，计算成本和参数数量均可以显著降低到1/8～1/9。

### 2.2 模型网络结构调整

为了在不影响模型性能的基础上，尽可能减少参数以及计算量的消耗，在本研究中，ShuffleNet

V2中Stage2、Stage3 和 Stage4的堆叠个数都降为1个。在网络初始3×3常规卷积之后，使用channel数为24、卷积核大小为3×3，步长为2的深度可分离卷积，以提出更加有效且丰富的特征，ShuffleNet V2网络结构如图1所示，改进后网络模型Shuffle-Hourglass SE的内部参数如表1所示，表中阶段2，阶段3，阶段4均由基本单元和下采样单元两部分组成，步长为2时，表示使用下采样单元缩小输出的尺寸，步长为1时，使用基本单元特征提取，此时不进行下采样操作。

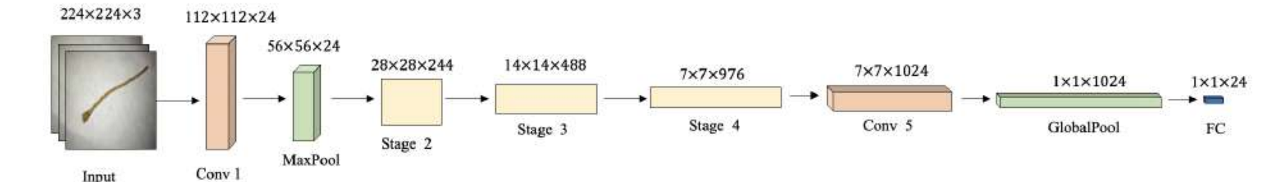



图1 ShuffleNet V2网络结构

Fig. 1 Network architecture of ShuffleNet V2

表1 Shuffle-Hourglass SE模型内部参数

Table 1 Internal parameters of Shuffle-Hourglass SE model

| 结构层 | 输出尺寸 | 卷积核大小 | 步长 | 重复数/次 | 输出通道 |
|---|---|---|---|---|---|
| 输入 | 224×224 | —— | —— | —— | —— |
| 卷积1 | 112×112 | 3×3 | 2 | 1 | 24 |
| 深度可分卷积2 | 56×56 | 3×3 | 2 | 1 | 24 |
| 阶段2 | 28×28<br>28×28 | —— | 2<br>1 | 1<br>1 | 244 |
| 阶段3 | 14×14<br>14×14 | —— | 2<br>1 | 1<br>1 | 488 |
| 阶段4 | 7×7<br>7×7 | —— | 2<br>1 | 1<br>1 | 976 |
| 卷积5 | 7×7 | —— | 1 | 1 | 2048 |
| 平均池化 | 1×1 | 7×7 | —— | —— | —— |
| 全连接 | —— | —— | —— | —— | 吉林/内蒙古/甘肃/黑龙江/河北 |

## 2.3 附加信道注意力的沙漏残差网络

ShuffleNet [22]、MobileNet [21]、Xception [19]、ResNet [13]等利用信道混洗和深度可分离卷积来优化ResNet的残差结构，既保证了网络的准确性，又提高了模型的运算效率。与倒残差模块不同，沙漏残差网络可以从高维特征获取到更多的信息，并解决shortcut连接所带来的梯度问题。使用深度卷积，然后利用批量标准化和激活函数将输入特征图分为两批X1和X2，X2通过深度可分离卷积、两次1×1卷积、再进行深度可分离卷积，然后利用批量标准化、Sigmoid激活函数[25]和X1和X2与深度和非深度特征融合，最后使用信道混洗[26]来混合深度和非深层特征。在特征向量中加入了激活函数和线性映射，增加了更多的非线性条件，可以更好地拟合通道之间的复杂相关性，最后，将计算出的通道特征与原始特征图相乘，得到通道保持的输出。挤压和激励结构SE（Squeeze-and-Excitation）模块的结构如图2所示。首先，具有通道总数$C$和大小$H\times W$的特征图U通过全局池$F_{sq}$被平坦化为（1，1，$C$）的特征向量，如公式（2）所示。

$$Z_c = F_{sq}(u_c) = \frac{1}{H \times W}\sum_{i=1}^{H}\sum_{j=1}^{W} u_c(i,j) \tag{2}$$

其中，$F_{sq}$为压缩操作；$u_c$是特征图U被平坦化为（1，1，$C$）；$Z_c$为关注的通道数。

将SE通道注意力[27]模块插入沙漏残差网络的深度可分离卷积后，对深度可分离卷积的输出进行

通道维度的特征提取，附加信道注意力的沙漏残差网络结构模型如图 3 所示，通道混洗过程如图 4 所示。

图 2 挤压和激励块结构(SE 模块)

Fig. 2 Structure of extrusion and excitation block（SE module）

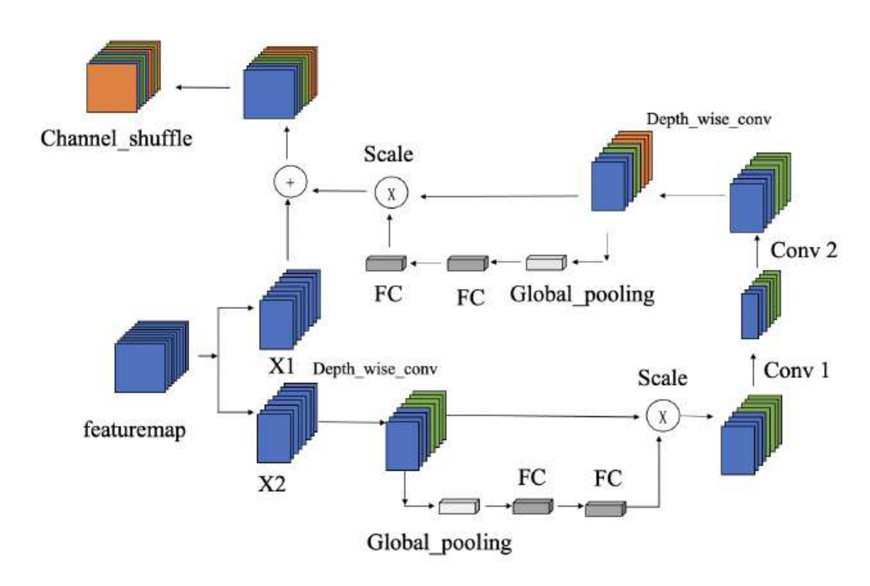



图 3 附加信道注意力的沙漏残差网络

Fig. 3 Hourglass residual network with additional channel attention

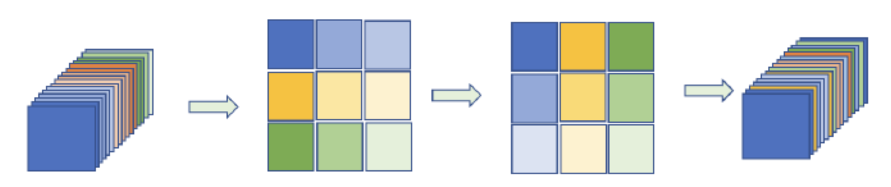


图 4 通道混洗过程

Fig. 4 Channel mixing process

## 2.4 SiLU 激活函数

不同产地的防风间存在数据不平衡问题，图片数量较少的类别在训练过程中容易出现过拟合现象，ShuffleNet V2 中的 ReLU 激活函数，通过引入 ReLU 输入的稀疏性，可以减少 ReLU 输入的不必要负值，可以提高训练网络的泛化能力，如公式（3）所示。

$$f(x) = \max(0, x) \tag{3}$$

其中，$x$ 为激活函数的输入；max( )为求最大值函数。

SiLU 激活函数[28]在保留 ReLU 激活函数优点的同时，可以更好地解决神经元坏死问题，函数表达式如公式（4）所示。ReLU 和 SiLU 函数对比图像如图 5 所示，与 ReLU 不同，SiLU 是平滑的、非单调的，将 SiLU 激活函数替换 ShuffleNet V2 下采

样单元和基本单元中的 ReLU 激活函数，可以提高模型的整体性能。

$$f(x) = \frac{x}{1 + e^{x}} \tag{4}$$

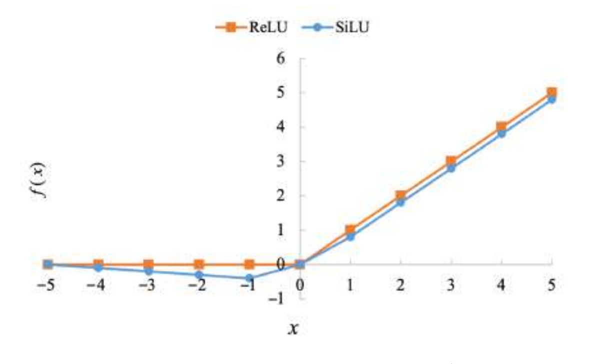



图 5 SiLU 和 ReLU 函数对比图像

Fig. 5 SiLU and ReLU functions compare image

### 2.5 ShuffleNet V2 网络结构改进

研究发现，反向残差块是由中间扩展层编码的特征图首先投影到低维特征图，存在信道压缩而无法保留足够的有用信息的问题，沙漏残差块主分支中的第一个和最后一个卷积层是保留通道的空间深度卷积层，可以从高维特征获取到更多的信息。经借鉴沙漏残差重要思想，本研究将改进的残差模块引进到 ShuffleNet V2 中，用沙漏残差网络代替倒残差网络，将 SE 通道注意力模块插入沙漏残差网络的深度可分离卷积后，把具有附加信道注意力的沙漏残差网络嵌入 ShuffleNet V2 中，SE 注意力通过控制通道比例的大小来增强重要特征，削弱不重要特征，使提取的特征更有方向性。用 SiLU 替换 ShuffleNet V2 下采样单元和基本单元中的 ReLU 激活函数，可以增强模型的泛化能力，同时在不降低网络性能的情况下调整模型架构，减少模型参数量和计算量。本研究提出的改进的 ShuffleNet V2 网络结构——ShuffleNet-Hourglass SE 模型如图 6 所示。

## 3 试验及结果分析

### 3.1 数据集来源及预处理

本研究所用防风样品由吉林农业大学中药材学院实验室提供，均为主要产区的正品样本，包括来自黑龙江、吉林、河北、甘肃、内蒙古 5 个产地共计 1000 余份。在室内白日光下使用手机拍摄获取 5 个产地的防风药材图像共 5234 幅，充分考虑了不同防风的地域分布差异。利用随机翻转、随机裁剪、亮度和对比度增强等处理，将数据集扩充至 10,120 幅防风图像，增强数据样本，部分数据集图像如图 7 所示。将整个数据集的 80% 作为训练集，另外 20% 作为测试集，数据集划分如表 2 所示。

### 3.2 试验设置

为了保证迭代效率并提高模型的稳定性和可推广性，每幅输入图像像素大小被固定为 224×224，优化器使用 Adam，批次大小设置为 32，学习率初始化为 0.001，迭代次数为 50 次，试验在 Linux 操作系统上进行，CPU 型号为 Intel（R） Core（TM） i7-10900K，RAM 为 32 GB 的 DDR4，CUDA 版本为 11.4，并构建基于 Python 3.9 编程语言的 Pytorch 深度学习框架。

### 3.3 模型评估标准

通过召回率（Recall）、精确率（Precision）、准确率（Accuracy）、$F_1$ 分数（$F_1$ score）等相关参数进行网络性能评估，其相关计算如公式（5）～（8）所示，并且把模型参数量和模型在单幅防风图片识别上的平均时间作为模型复杂度的对比指标[29]。

$$Accuracy = \frac{\mathrm{TP + TN}}{\mathrm{TP + TN + FP + TN}} \times 100\% \tag{5}$$

$$Precision = \frac{\mathrm{TP}}{\mathrm{TP + FP}} \times 100\% \tag{6}$$

$$Recall = \frac{\mathrm{TP}}{\mathrm{TP + FP}} \times 100\% \tag{7}$$

$$F_1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\% \tag{8}$$

其中，TP 为网络识别正确的正样本的数量；TN 为网络错误识别的负样本数量；FP 为网络错误识别的正样本数量。

### 3.4 实验结果与分析

#### 3.4.1 不同模型性能对比实验

为了评价本研究所提出模型的有效性，选择 VGG16、MobileNet V2、ShuffleNet V2 和 SqueezeNet V2 四种模型与本模型[30]进行对比实验。为保证对比合理性，五种模型均使用本文所提出的数据集，

图 6　ShuffleNet-Hourglass SE 防风识别模型

Fig. 6　*Saposhnikovia divaricata*（Turcz.）Schischk identification model ShuffleNet-Hourglass SE




图 7　防风的部分数据集图像

Fig. 7　Selected images of the dataset for *Saposhnikovia divaricata*（Turcz.）Schischk

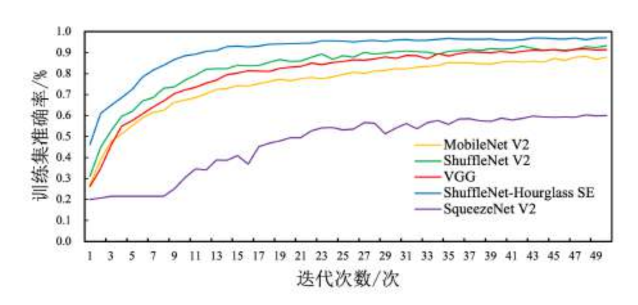
**表 2　防风数据集划分**

Table 2　Dataset division of *Saposhnikovia divaricata*（Turcz.）Schischk

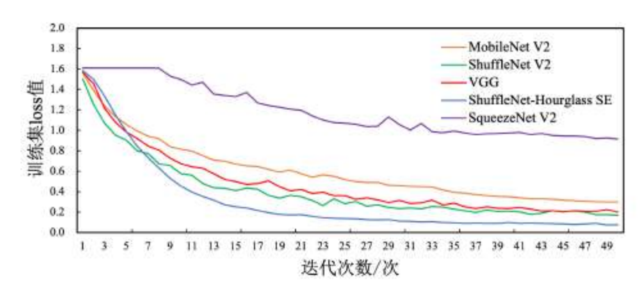
| 原产地 | 测试集/幅 | 训练集/幅 | 图像数量/幅 |
|---|---|---|---|
| 甘肃 | 404 | 1617 | 2021 |
| 河北 | 398 | 1589 | 1987 |
| 黑龙江 | 411 | 1642 | 2053 |
| 吉林 | 470 | 1879 | 2349 |
| 内蒙古 | 342 | 1368 | 1710 |

并在相同的参数下进行训练，最后通过在测试集和训练集损失值、准确率、召回率、$F_1$分数作为模型性能的评价指标，实验结果如图 8 和图 9 所示。

从图 8 和图 9 可以看出，本研究所提出的 Shuffle-Hourglass SE 模型实现了更低的损失值和更高的



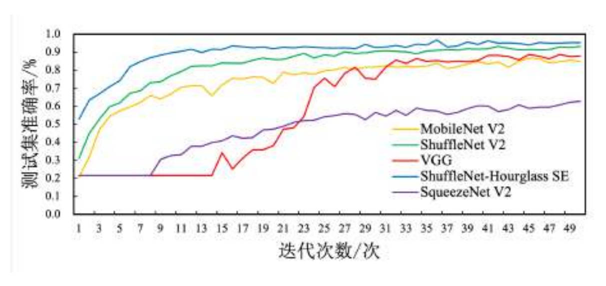

(a)不同模型在训练集的准确率曲线图



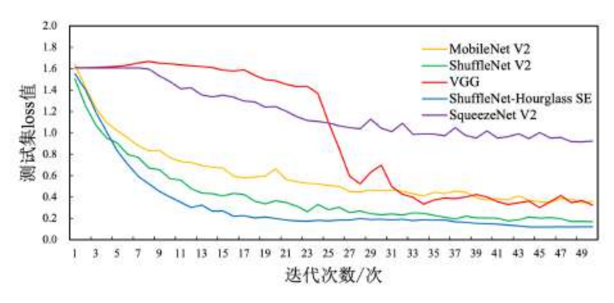

(b)不同模型在训练集的loss值曲线图

图8 不同模型在训练集的准确率和loss值曲线图

Fig. 8 Accuracy and loss curves of different models in the training set




(a)不同模型在测试集的准确率曲线图




(b)不同模型在测试集的loss值曲线图

图9 不同模型在测试集的准确率和损失值曲线图

Fig. 9 Accuracy and loss curves of different models in the test set

准确率，在训练集和测试集上的损失值分别为0.075和0.122。同时，可以看出本研究模型的收敛速度优于ShuffleNet V2，在20次epoch左右趋于收敛，能够在最短时间内训练出最优的模型且更稳定。总体来看各个模型的loss和accuracy收敛曲线，在测试集上损失值略高于训练集，在测试集上accuracy略低于训练集。不同模型在测试集上的实验结果如表3所示。

**表3 不同模型在测试集上的实验结果**

Table 3 Experimental results of different models on the test set

| 模型 | 准确率/% | 测试时长/ms | 召回率/% | $F_1$分数/% | 模型大小/M |
|---|---|---|---|---|---|
| MobileNet V2 | 84.82 | 315.65 | 84.91 | 84.46 | 5.21 |
| ShuffleNet V2 | 93.23 | 324.54 | 93.18 | 93.08 | 4.52 |
| VGG | 87.91 | 876.54 | 88.02 | 87.82 | 99.72 |
| Shuffle-Hourglass SE | 95.32 | 246.34 | 95.28 | 95.27 | 3.23 |
| SqueezeNet V2 | 62.71 | 161.98 | 62.88 | 62.43 | 6.03 |

由表3可知，本研究提出的模型Shuffle-Hourglass SE获得了最佳性能。在测试集上取得95.32%的准确率、95.28%的召回率，$F_1$分数达到95.27%，均优于未改进的ShuffleNet V2模型，并比ShuffleNet V2模型分别提高了2.09%、2.1%和2.19%。测试时间、模型大小为246.34 ms和3.23 M，不仅在传统CNN网络中是最优的，在轻量级网络中也具有较大优势。

和经典卷积网络VGG相比，本研究提出的Shuffle-Hourglass SE模型准确率提高7.41%，测试时间缩减71.89%，模型大小缩减96.76%。尽管ShuffleNet V2和MobileNet V2的测试时间相近，但改进的Shuffle-Hourglass SE模型的准确率和速度证明了其性能的有效性，测试时间比MobileNet V2缩减69.31 ms，模型大小缩减1.98 M，准确率提高10.5%。在分类精度方面，改进后的网络保持了较高的识别精度，并且分类性能良好，类似地与未改进的ShuffleNet相比有所改进，与其他轻量级网络相比有显著改进。

综上所述，本研究提出的模型可以显著提高计算效率，同时在分类精度方面获得良好的性能，从而在模型大小和性能之间取得合理的平衡。

### 3.4.2 不同注意力机制对模型性能的影响

为了验证本研究提出的SE注意力机制在附加信道注意力的沙漏残差网络的有效性，与ECA（Efficient Channel Attention）注意力机制[30]、CBAM（Convolutional Block Attention Module）注意力机制[31]、CA注意力机制[32]进行对比，所有

注意力机制引入到ShuffleNet V2模型中的相同位置，实验结果如表4所示。对比ECA注意力机制，在模型中引入SE注意力机制的准确率和$F_1$分数更高，可以更好地实现通道间的信息交互提升模型性能。相比于CA注意力机制，引入SE注意力机制准确率和$F_1$分数分别提升了0.68%和0.82%，参数量减0.51 M；相比于CBAM注意力机制，引入SE注意力机制，模型的准确率和$F_1$分数分别提升了1.19%和1.38%，参数量未变化。因此，本研究提出的SE注意力机制具有更优参数量的同时，模型的准确率和$F_1$分数更高。

**表 4　不同注意力机制对模型性能的影响**

Table 4　Effects of different attention mechanisms on model performances

| 注意力机制 | 准确率/% | 召回率/% | $F_1$分数/% | 参数量/M |
|---|---|---|---|---|
| ECA | 93.72 | 93.88 | 93.45 | 4.52 |
| SE | 95.32 | 95.44 | 95.31 | 4.39 |
| CA | 94.64 | 94.75 | 94.49 | 4.98 |
| CBAM | 94.13 | 94.22 | 93.93 | 4.52 |

### 3.4.3　不同激活函数对模型性能的影响

本研究将ShuffleNet V2模型下采样单元和基本单元中的ReLU激活函数被SiLU替换，可以增强模型的泛化能力。为验证其有效性，在其他参数均不变情况下选取ReLU、H-swish[33]、ELU[34]激活函数进行对比，实验结果如表5所示。从表5可以看出，相比于ReLU激活函数，使用ELU激活函数的模型效果较差；使用H-Swish激活函数的模型准确率和$F_1$分数略有提升；使用SiLU激活函数的模型准确率可达到95.32%，准确率和$F_1$分数分别提升了2.09%和1.93%，取得了最佳效果。

### 3.4.4　Shuffle-Hourglass SE模型的消融实验结果

为了探究使用SE模块注意力机制、沙漏残差块和激活函数的改进方式对ShuffleNet V2模型带来的性能提升[34]，本研究进行Shuffle-Hourglass SE模型消融实验，实验结果如表6所示。

**表 5　不同激活函数对模型性能的影响**

Table 5　Effects of different activation functions on model performances

| 激活函数 | 准确率/% | $F_1$分数/% |
|---|---|---|
| ReLU | 93.23 | 93.11 |
| H-Swish | 94.08 | 93.88 |
| ELU | 92.98 | 92.96 |
| SiLU | 95.32 | 95.04 |

**表 6　Shuffle-Hourglass SE模型消融实验结果**

Table 6　Ablation results of Shuffle-Hourglass SE model

| 模型 | 因素 | | | | 准确率/% | 参数量 |
|---|---|---|---|---|---|---|
| | 注意力机制模块 | 沙漏残差块 | 激活函数 | 架构调整 | | |
| ShuffleNet V2 | × | × | × | × | 93.23 | 4.52 |
| | √ | × | × | × | 94.53 | 4.52 |
| | × | √ | × | × | 94.12 | 5.56 |
| | × | × | √ | × | 94.44 | 4.52 |
| | √ | √ | × | × | 94.92 | 5.56 |
| | √ | √ | √ | × | 95.03 | 5.56 |
| Shuffle-Hourglass SE | √ | √ | √ | √ | 95.32 | 3.23 |

由表6可以看出，在ShuffleNet V2中增加SE注意力机制，模型的准确率提升了1.3%，将沙漏残差模块引入ShuffleNet V2的基本单元中，模型的准确率提升了0.89%，但是模型的参数量增加较多，使用SiLU替换ReLU激活函数，模型整体准确率提高了1.21%。通过调整模型架构，模型的参数量和计算量显著降低。最终，本研究提出的Shuffle-Hourglass SE模型的准确率和参数量为95.32%和3.23 M，相比于改进之前的ShuffleNet V2，准确率上升了2.09%，参数量减少了1.29 M。

## 4　结　论

本研究针对防风同物种空间形态和颜色纹理特征较为复杂，区分度较低等特点，提出了一种基于注意力嵌入ShuffleNet V2的防风道地性识别网络模型（Shuffle-Hourglass SE），使用自主拍摄的防风图像构建数据集，并对其进行加强。

（1）选用ShuffleNet V2为基础网络架构，用沙漏残差网络代替传统残差网络，同时引入SE注意力机制，把具有附加信道注意力的沙漏残差网络嵌入到ShuffleNet V2中，丰富不同产地防风的局部特征学习，优化道地性识别模型，使用SiLU激活函数替换ReLU激活函数，进一步提高了ShuffleNet V2的性能。

（2）改进后的Shuffle-Hourglass SE模型在自建

数据集上的准确率可达95.32%，模型大小仅为3.23 MB，在相同测试集的情况下，准确率和$F_1$分数分别提高了1.69%和1.23%，模型大小缩小96.76%。李东明等[16]所提出的采用改进稠密连接网络的防风药材的道地性识别方法，虽然识别率可达到97.23%，比本研究所提出的模型识别率高1.91%，但本研究所提出的模型在参数量、测试时间和模型大小上要优于该网络。

本模型在保持较高识别精度的同时占用较少的存储空间，而且在测试时间上具有一定优势，同时具有高度便携性，有助于在未来的低性能终端上实现防风道地性的实时诊断。

**利益冲突声明：**本研究不存在研究者以及与公开研究成果有关的利益冲突。



**参考文献：**

[1] 程显隆, 郭晓晗, 李明华, 等. 道地性和生产规范性是中药材质量属性形成的关键[J]. 中国现代中药, 2020, 22(7): 991-995, 1155.
CHENG X L, GUO X H, LI M H, et al. Daodi attribute and production standardization are the key to the formation of the quality attributes of Chinese materia *Medica*[J]. Modern Chinese medicine, 2020, 22(7): 991-995, 1155.

[2] 胡云飞. 基于药物分析组合技术研究凤丹药材的道地性[D]. 合肥: 安徽中医药大学, 2015.
HU Y F. Studies on the genuineness of Feng Dan based on the combination technology of pharmaceutical analysis[D]. Hefei: Anhui University of Chinese Medicine, 2015.

[3] 张冬月, 吴浩善, 李思雨, 等. 电子鼻技术鉴别通关藤真伪及其道地性[J]. 中成药, 2018, 40(10): 2228-2233.
ZHANG D Y, WU H S, LI S Y, et al. Authenticity and genuineness identification of *Marsdenia tenacissima* by electronic nose[J]. Chinese traditional patent medicine, 2018, 40(10): 2228-2233.

[4] 刘飞, 王元忠, 杨春艳, 等. 红外光谱结合判别分析对三七道地性及产地的鉴别研究[J]. 光谱学与光谱分析, 2015, 35(1): 108-112.
LIU F, WANG Y Z, YANG C Y, et al. Study on the genuineness and producing area of *Panax notoginseng* based on infrared spectroscopy combined with discriminant analysis[J]. Spectroscopy and spectral analysis, 2015, 35(1): 108-112.

[5] ZHANG T C, LI S, WANG Y H, et al. Research progress in the application of stable isotope and mineral element analysis in tracing the geographical origin of Chinese medicinal materials[J]. Food science and technology, 2022, 42: ID e08222.

[6] DENG L. Deep learning: Methods and applications[J]. Foundations and trends® in signal processing, 2014, 7(3/4): 197-387.

[7] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.

[8] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2015: 3431-3440.

[9] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(6): 1137-1149.

[10] YUAN Z W, ZHANG J. Feature extraction and image retrieval based on AlexNet[C]// Proc SPIE 10033, eighth international conference on digital image processing (ICDIP 2016), 2016, 10033: 65-69.

[11] HE J, LI S, SHEN J M, et al. Facial expression recognition based on VGGNet convolutional neural network[C]// 2018 Chinese Automation Congress (CAC). Piscataway, NJ, USA: IEEE, 2019: 4146-4151.

[12] AL-QIZWINI M, BARJASTEH I, AL-QASSAB H, et al. Deep learning algorithm for autonomous driving using GoogLeNet[C]// 2017 IEEE Intelligent Vehicles Symposium (IV). Piscataway, NJ, USA: IEEE, 2017: 89-96.

[13] TARG S, ALMEIDA D, LYMAN K. Resnet in resnet: Generalizing residual architectures[EB/OL]. arXiv: 1603.08029, 2016.

[14] ZHU Y, NEWSAM S. DenseNet for dense flow[C]// 2017 IEEE International Conference on Image Processing (ICIP). Piscataway, NJ, USA: IEEE, 2018: 790-794.

[15] 赵潇潇. 一种基于外观图像的枸杞道地性AI识别研究[D]. 天津: 天津科技大学, 2021.
ZHAO X X. A study on the recognition of genuine AI of Lycium barbarum based on appearance image [D].Tianjin: Tianjin University of Science & Technology, 2021.

[16] 李东明, 汤鹏, 张丽娟, 等. 采用改进稠密连接网络的防风药材的道地性识别[J]. 农业工程学报, 2022, 38(3): 276-285.
LI D M, TANG P, ZHANG L J, et al. Genuine identification for *Saposhnikovia divaricata* based on improved DenseNet[J]. Transactions of the Chinese society of agricultural engineering, 2022, 38(3): 276-285.

[17] LYU B J, WU L Y, HUANGFU T R, et al. Traditional Chinese medicine recognition based on target detection[J]. Evidence-based complementary and alternative medicine, 2022, 2022: 1-9.

[18] XING C Y, HUO Y Q, HUANG X J, et al. Research on image recognition technology of traditional Chinese medicine based on deep transfer learning[C]// 2020 International Conference on Artificial Intelligence and Electromechanical Automation (AIEA). Piscataway, NJ, USA: IEEE, 2020: 140-146.

[19] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 1800-1807.
[20] SINHA D, EL-SHARKAWY M. Thin MobileNet: An enhanced MobileNet architecture[C]// 2019 IEEE 10th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON). Piscataway, NJ, USA: IEEE, 2020: 280-285.
[21] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 4510-4520.
[22] MA N N, ZHANG X Y, ZHENG H T, et al. ShuffleNet V2: Practical guidelines for efficient CNN architecture design[C]// Computer Vision - ECCV 2018: 15th European Conference, Munich, Germany, September 8-14, 2018, Proceedings, Part XIV. New York, USA: ACM, 2018: 122-138.
[23] 刘雪纯, 刘大铭, 常佳鑫, 等. 基于MobileNet V2迁移学习的中药材图像识别[J]. 长江信息通信, 2022, 35(7): 33-37, 44.
LIU X C, LIU D M, CHANG J X, et al. MobileNet V2 migration learning based image recognition of Chinese herbs[J]. Changjiang information & communications, 2022, 35(7): 33-37, 44.
[24] XIANG Q, WANG X D, LI R, et al. Fruit image classification based on MobileNetV2 with transfer learning technique[C]// Proceedings of the 3rd International Conference on Computer Science and Application Engineering. New York, USA: ACM, 2019: 1-7.
[25] ZHU H G, ZENG H M, LIU J H, et al. Logish: A new nonlinear nonmonotonic activation function for convolutional neural network[J]. Neurocomputing, 2021, 458: 490-499.
[26] TANG Z, YANG J L, LI Z, et al. Grape disease image classification based on lightweight convolution neural networks and channelwise attention[J]. Computers and electronics in agriculture, 2020, 178: ID 105735.
[27] LI Y, LIU Y, CUI W G, et al. Epileptic seizure detection in EEG signals using a unified temporal-spectral squeeze-and-excitation network[J]. IEEE transactions on neural systems and rehabilitation engineering, 2020, 28(4): 782-794.
[28] KARAMAN A, PACAL I, BASTURK A, et al. Robust real-time polyp detection system design based on YOLO algorithms by optimizing activation functions and hyper-parameters with artificial bee colony (ABC)[J]. Expert systems with applications, 2023, 221: ID 119741.
[29] 张旭, 周云成, 刘忠颖, 等. 基于改进Shufflenet V2模型的苹果叶部病害识别及应用[J]. 沈阳农业大学学报, 2022, 53(1): 110-118.
ZHANG X, ZHOU Y C, LIU Z Y, et al. Identification and application of apple leaf diseases based on improved Shufflenet V2 model[J]. Journal of Shenyang agricultural university, 2022, 53(1): 110-118.
[30] 李好, 邱卫根, 张立臣. 改进ShuffleNet V2的轻量级农作物病害识别方法[J]. 计算机工程与应用, 2022, 58(12): 260-268.
LI H, QIU W G, ZHANG L C. Improved ShuffleNet V2 for lightweight crop disease identification[J]. Computer engineering and applications, 2022, 58(12): 260-268.
[31] ZUO Y M, LIU P S, TAN Y Q, et al. An attention-based lightweight residual network for plant disease recognition[C]// 2020 International Conference on Artificial Intelligence and Computer Engineering (ICAICE). Piscataway, NJ, USA: IEEE, 2021: 224-228.
[32] 周剑, 谢知音. 基于注意力机制的改进残差网络的柑橘分类研究[J]. 现代农业装备, 2023, 44(1): 47-55.
ZHOU J, XIE Z Y. Research on *Citrus* classification based on improved residual network and attention mechanism[J]. Modern agricultural equipment, 2023, 44(1): 47-55.
[33] 徐增敏, 陈凯, 郭威伟, 等. 面向轻量级卷积网络的激活函数与压缩模型[J]. 计算机工程, 2022, 48(5): 242-250.
XU Z M, CHEN K, GUO W W, et al. Activation function and compression model for lightweight convolutional network[J]. Computer engineering, 2022, 48(5): 242-250.
[34] 彭红星, 徐慧明, 刘华鼐. 基于改进ShuffleNet V2的轻量化农作物害虫识别模型[J]. 农业工程学报, 2022, 38(11): 161-170.
PENG H X, XU H M, LIU H N. Lightweight agricultural crops pest identification model using improved ShuffleNet V2[J]. Transactions of the Chinese society of agricultural engineering, 2022, 38(11): 161-170.

# Lightweight Intelligent Recognition of *Saposhnikovia Divaricata* (Turcz.) Schischk Originality Based on Improved ShuffleNet V2

ZHAO Yu[1], REN Yiping[2], PIAO Xinru[1], ZHENG Danyang[1], LI Dongming[1,3*]

(1. *School of Information Technology*, *Jilin Agricultural University*, *Changchun* 130118, *China*; 2. *School of Life Science*, *Jilin Ag-*

*ricultural University*, *Changchun* 130118, *China*; 3. *School of Internet of Things Engineering*, *Wuxi College*, *Wuxi* 214063, *China*)

**Abstract:**

**[Objective]** *Saposhnikovia divaricata* (Turcz.) Schischk is a kind of traditional Chinese medicine. Currently, the methods of identifying the origin and quality of *Saposhnikovia divaricata* (Turcz.) Schischk are mainly based on their physical or chemical characteristics, which is impossible to make an accurate measurement of Groundness identification. With the continuous development of deep learning, its advantages of no manual extraction and high classification accuracy are widely used in different fields, and an attention-embedded ShuffleNet V2-based model was proposed in this study to address the problems of large computation and low accuracy of most convolutional neural network models in the identification of Chinese herbal medicine *Saposhnikovia divaricata* (Turcz.) Schischk.

**[Methods]** The model architecture was adjusted to reduce the number of model parameters and computation without degrading the network performance, and the traditional residual network was replaced by the Hourglass residual network, while the SE attention mechanism was introduced to embed the hourglass residual network with additional channel attention into ShuffleNet V2. The important features were enhanced and  the unimportant features were weakened by controlling the size of the channel ratio to make the extracted features more directional by SE attention. The SiLU activation function was used to replace the ReLU activation function to enhance the generalization ability of the model Enriching local feature learning. Therefore, a lightweight Shuffle-Hourglass SE model was proposed. The samples of *Saposhnikovia divaricata* (Turcz.) Schischk used in this research were samples from the main production areas, including more than 1000 samples from five production areas in Heilongjiang, Jilin, Hebei, Gansu and Inner Mongolia. A total of 5234 images of *Saposhnikovia divaricata* (Turcz.) Schischk were obtained by using cell phone photography indoors under white daylight, fully taking into account the geographical distribution differences of different *Saposhnikovia divaricata* (Turcz.) Schischk. The data set of *Saposhnikovia divaricata* (Turcz.) Schischk images was expanded to 10,120 by using random flip, random crop, brightness and contrast enhancement processes. In order to verify the effectiveness of the model proposed, four classical network models, VGG16, MobileNet V2, ShuffleNet V2 and SqueezeNet V2, were selected for comparison experiments, ECA ( Efficient Channel Attention ) attention mechanism, CBAM ( Convolutional Block Attention Module ) attention mechanism and CA attention mechanism were chosen to compare with SE. All attention mechanisms were introduced into the same position in the ShuffleNet V2 model, and ReLU, H-swish and ELU activation functions were selected for contrast experiments under the condition in which other parameters unchanged. In order to explore the performance improvement of ShuffleNet V2 model by using the attention mechanism of SE module, Hourglass residual block and activation function, Shuffle-Hourglass SE model ablation experiment was carried out. Finally, loss, accuracy, precision, recall and $F_1$ score in test set and training set were used as evaluation indexes of model performances.

**[Results and Discussions]** The results showed that the Shuffle-Hourglass SE model proposed achieved the best performances. An accuracy of 95.32%, recall of 95.28%, and $F_1$ score of 95.27% were obtained in the test set, which was 2.09%, 2.1 %, and 2.19 % higher than the ShuffleNet V2 model, respectively. The test duration and model size were 246.34 ms and 3.23 M, respectively, which were not only optimal among Traditional CNN such as VGG and Desnet,but had great advantages among lightweight networks such as MobileNet V2、SqueezeNet V2 and ShuffleNet V2. Compared with the classical convolutional network VGG, 7.41% of the accuracy was improved, 71.89% of the test duration was reduced, and 96.76% of the model size was reduced by the Shuffle-Hourglass SE model proposed in this study. Although the test duration of ShuffleNet V2 and MobileNet V2 were similar, the accuracy and speed of the Shuffle-Hourglass SE model improved, which proved its better performance. Compared with MobileNet V2, the test duration was reduced by 69.31 ms, the model size was reduced by 1.98 M, and the accuracy was increased by 10.5 %. In terms of classification accuracy, the improved network maintains higher recognition accuracy and better classification performance.

**[Conclusions]** The model proposed in this research is able to identify the *Saposhnikovia divaricata* (Turcz.) Schischk originality well while maintaining high identification accuracy and consuming less storage space, which is helpful for realizing real-time identification of *Saposhnikovia divaricata* (Turcz.) Schischk originality in the future low performance terminals.

**Key words:** *Saposhnikovia divaricata* (Turcz.) Schischk; originality recognition; ShuffleNet V2; SE attention mechanism; hourglass residual network; traditional Chinese medicine; lightweight model